

VŠB – Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky
Katedra kybernetiky a biomedicínského inženýrství

**Rekonstrukce obrazu z naměřených dat v elektrické
impedanční tomografii**
**Image reconstruction of measured data in electrical
impedance tomography**

Ostrava, 2015

Veronika Cedivodová

VŠB - Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky
Katedra kybernetiky a biomedicínského inženýrství

Zadání bakalářské práce

Student: **Veronika Cedivodová**
Studijní program: B2649 Elektrotechnika
Studijní obor: 3901R039 Biomedicínský technik
Téma: Rekonstrukce obrazu z naměřených dat v elektrické
impedanční tomografii
Image Reconstruction of Measured Data in Electrical
Impedance Tomography

Zásady pro vypracování:

1. Popis bioimpedančního signálu.
2. Popis metody impedanční tomografie.
3. Rozbor metod rekonstrukce obrazu.
4. Popis neuronových sítí.
5. Návrh modelu neuronové sítě.
6. Testování modelu neuronové sítě.
7. Zhodnocení dosažených výsledků práce .

Seznam doporučené odborné literatury:

- [1] PENHAKER, Marek a Martin AUGUSTYNEK. *Zdravotnické elektrické přístroje I*. 1. vyd. Ostrava: VŠB - Technická univerzita Ostrava, 2013, 411 s. ISBN 978-80-248-3107-7.
- [2] GRIMNES, Sverre a Orjan G. MARTINSEN. *Bioelectricity and bioimpedance basics*. 2nd ed. London: Academic, 2008. ISBN 978-0-12-374004-5.
- [3] BRECKON, William R. *Image Reconstruction In Electrical Impedance Tomography*. Manchester: The University of Manchester, Manchester Institute for Mathematical Sciences, School of Mathematics, 1990. PhD thesis. ISSN 1749-9097. Dostupné také z:
http://eprints.ma.man.ac.uk/1083/01/covered/MIMS_ep2008_48.pdf.
- [4] VALA, Peter. *Měření multifrekvenční elektrické impedanční tomografie*. Ostrava, 2013. Diplomová práce. VŠB - Technická univerzita Ostrava, Fakulta elektrotechniky a informatiky, Katedra kybernetiky a biomedicínského inženýrství.

Formální náležitosti a rozsah bakalářské práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.

Vedoucí bakalářské práce: **Ing. Markéta Michalíková**

Datum zadání: 01.09.2014

Datum odevzdání: 07.05.2015



doc. Ing. Jiří Koziorek, Ph.D.
vedoucí katedry



prof. RNDr. Václav Snášel, CSc.
děkan fakulty

Prohlášení

Prohlašuji, že jsem tuto bakalářskou práci vypracovala samostatně.

Uvedla jsem všechny použité literární zdroje a publikace, ze kterých jsem čerpala.



Veronika Cedivodová

Datum odevzdání bakalářské práce: 7. 5. 2015

Poděkování

Tímto bych ráda poděkovala své vedoucí bakalářské práce Ing. Markétě Michalíkové za konzultace, cenné rady a trpělivost, čímž přispěla k vypracování zadaného úkolu. Dále patří poděkování mé rodině za trpělivost a morální podporu.

Abstrakt

Tato práce se skládá z teoretické a praktické části. V teoretické části je rozebrána problematika bioimpedance, metody elektrické impedanční tomografie, deterministické i stochastické metody rekonstrukce obrazu a problematika neuronových sítí. Praktická část se věnuje návrhu a realizaci rekonstrukce obrazu v EIT pomocí neuronových sítí. Pro usnadnění práce s programem bylo navrženo uživatelské rozhraní. Do tohoto rozhraní patří generování sad trénovacích a testovacích modelů a rekonstrukce obrazu pomocí neuronových sítí. V případě nejasností je zde nápověda, kde je popsáno, jak konkrétní tlačítko pracuje.

Klíčová slova

Bioimpedance, elektrická impedanční tomografie, rekonstrukce obrazu, neuronová síť, vícevrstvá perceptronová neuronová síť, neuronová síť založená na radiální bazické funkci.

Abstract

This thesis consists of theoretical and practical parts. In theoretical part are analyzed problems of bioimpedance, methods of electrical impedance tomography, deterministic and stochastic methods of image reconstruction and problems of neural networks. The practical part is dedicated to design and implementation of image reconstruction in EIT using neural networks. For convenience working with the program was designed user interface. Into this interface belongs generating training and testing sets of models and image reconstruction through the use of neural network. In case of doubt, there is help, where is subscribed how concrete button works.

Key word

Bioimpedance, electrical impedance tomography, image reconstruction, neural network, Multilayer Perceptron Neural Network (MLP), neural network based on radial basis function.

Seznam použitých symbolů a zkratek

CT	(Computed Tomography) počítačová tomografie
EIDORS	(Electrical Impedance Tomography and Diffuse Optical Tomography Reconstruction Software) Software pro rekonstrukci elektrické impedanční tomografie a difúzní optické tomografie
EIT	(Electrical Impedance Tomography) elektrická impedanční tomografie
FEM	(Finite Element Model) metoda konečných prvků
LSM	(Level Set Method) metoda nastavení úrovně
MSE	(Mean Squared Error) střední kvadratická chyba
MLP	(Multi Layer Perceptron Neural Network) vícevrstvá perceptronová síť
RBF	(Radial Basis Functions) radiální bazická funkce
TRM	(Tikhonov Regularization Method) Tichonova regularizační metoda
TV	(Total Variation) totální variace

Obsah

1	Úvod.....	2
2	Bioimpedance.....	3
2.1	Bioimpedanční signál.....	3
2.2	Elektrody pro měření bioimpedance	3
3	Elektronická impedanční tomografie	4
3.1	Princip metody	4
3.2	Dopředné řešení a inverzní úloha.....	5
4	Rekonstrukce obrazu.....	6
4.1	Projekce a Radonova transformace	6
4.2	Prostá zpětná projekce.....	7
4.3	Filtrovaná zpětná projekce (Inverzní Radonova transformace)	8
4.4	Fourierova rekonstrukce.....	8
4.5	Deterministické metody – elektrická impedanční tomografie.....	8
4.5.1	Metoda Tichonovovy regularizace.....	8
4.5.2	Metoda totální variace	9
4.5.3	Metoda nastavení úrovně	9
4.6	Stochastické metody-elektrická impedanční tomografie.....	9
4.6.1	Metoda diferenciální evoluce	9
4.7	Rekonstrukce obrazu pomocí neuronových sítí – elektrická impedanční tomografie.....	9
5	Neuronové sítě	11
5.1	Elektrické vlastnosti neuronu	11
5.2	Umělá neuronová síť	12
5.3	Typy neuronových sítí.....	12
5.3.1	Vícevrstvá perceptronová síť (Multilayer Perceptron Neural Network – MLP).....	12
5.3.2	Hopfieldova síť.....	13
5.3.3	Kohonenova síť	14
5.3.4	RBF síť (Radial Basis Functions)	14
6	Návrh řešení	16
7	Realizace	18
7.1	Generování trénovacích modelů.....	18

7.2	Trénování neuronové sítě typu RBF	20
7.3	Trénování vícevrstvé perceptronové sítě.....	22
7.4	Tvorba uživatelského rozhraní	24
8	Testování	26
8.1	Generování testovacích modelů	26
8.2	Testování neuronové sítě typu RBF	27
8.3	Testování vícevrstvé perceptronové sítě	28
9	Vyhodnocení rekonstrukce obrazu	30
9.1	Vyhodnocení rekonstrukce obrazu pro neuronovou síť typu RBF.....	30
9.2	Vyhodnocení rekonstrukce obrazu pro vícevrstvou perceptronovou síť.....	34
9.3	Porovnání výsledků rekonstrukce obrazu.....	35
10	Závěr	39
11	Použitá literatura	40
12	Seznam příloh.....	42

1 Úvod

Elektrická impedanční tomografie (EIT) je pomalu rozvíjející se zobrazovací metoda pro diagnostická vyšetření v lékařství. Tato neinvazivní metoda využívá různé elektrické vodivosti tkáně, kdy výsledkem je obraz vnitřního rozložení impedance tkáně v měřené oblasti. EIT zdaleka nedosahuje takových zobrazovacích výsledků jako například CT, proto se využívá nejčastěji jen pro zobrazení v oblasti hrudníku k diagnostice dýchacích cest. Výhodou EIT je nejen absence ionizujícího záření, malé rozměry, ale hlavně velmi nízká cena vzhledem k ostatním zobrazovacím metodám.

Rekonstrukční algoritmy v elektrické impedanční tomografii jsou různě složité a podle toho, na jakém principu jsou založeny, se dělí na deterministické a stochastické. Tato práce se zaměřuje na zvláštní odvětví rekonstrukce obrazu založeném na neuronových sítích. Existují různé typy neuronových sítí např. vícevrstvá perceptronová síť (Multilayer Perceptron Neural Network, MLP), Hopfieldova síť, Kohonenova síť a RBF síť (Radial Basis Functions). Cílem této práce je provedení rekonstrukce obrazu v EIT pomocí natrénovaných neuronových sítí. Výsledná rekonstrukce obrazu pomocí neuronových sítí se následně porovná s originálním vygenerovaným modelem a zhodnotí v závěru práce.

V kapitole 2 je rozebrána problematika bioimpedance, tato kapitola se bude dále zabývat problematikou bioimpedančního signálu a druhy elektrod pro měření bioimpedance. V kapitole 3 bude popsána elektrická impedanční tomografie, konkrétně pak dopředná a inverzní úloha. Kapitola 4 bude věnována samotné rekonstrukci obrazu a budou zde popsány různé rekonstrukční algoritmy. V kapitole 5 bude popsána neuronová síť, její princip a typy těchto sítí.

Samotný návrh generovaných impedančních modelů, neuronové sítě a uživatelského rozhraní bude rozebrán v kapitole 6. Kapitola 7 bude věnována realizaci daného problému. Tedy je zde rozebráno vytvoření uživatelského prostředí, kde patří tvorba trénovacích a testovacích modelů, trénink neuronových sítí a jejich testování a následná rekonstrukce obrazu. Samotným testováním neuronové sítě se podrobněji zabývá kapitola 8. V kapitole 9 pak budou vyhodnoceny výsledky rekonstrukce.

2 Bioimpedance

Bioimpedance se zabývá některými pasivními elektrickými vlastnostmi tkání, např. schopností odporu (impedance) toku elektrického proudu. Bioimpedanční metody využívají elektrody s galvanickou vazbou na tkáň. Tkáň je považována z hlediska jejich elektrických vlastností za objemový vodič nebo dielektrikum.

Bioimpedance se zabývá tzv. biomateriály, ať už jsou to materiály, které žijí, žili, či vykazují potenciál pro život. Může to být také mrtvý biologický materiál, jako jsou vlasy nebo nehty, či vyříznutý materiál, jako je sval či kousek rohovky.

Impedance je poměr mezi napětím a proudem. Toto platí u stejnosměrného a střídavého proudu. Admittance je opakem impedance, jelikož tkáň toku proudu neodporuje, ale propouští jej. Souhrnný název pro impedanci a admittanci je imitance, proto by se měl používat v souvislosti s bioimpedancí název bioimitance.

Dielektrikum je v podstatě jakýkoliv materiál, nejčastěji suchý izolant, který je umístěn mezi deskami kondenzátoru. Elektrostatické pole nemůže projít kovem, ale může projít dielektrikem. Nejdůležitější elektrickou vlastností dielektrika je permitivita ϵ . Permitivita vyjadřuje vliv látky na elektrické pole. Za stejných podmínek platí, že admittance Y , impedance Z tzn. převrácená hodnota Y a permitivita ϵ mají stejný význam jen jinak prezentovaný [2].

2.1 Bioimpedanční signál

Bioimpedanční signál se generuje vhodnou indikací střídavého proudu o frekvenci desítek kHz do tkáně. Na jiném místě na povrchu těla je snímán pomocí jiných elektrod napěťový signál, tedy to napětí, které vzniká při průchodu indukovaného proudu tkání. Jeho velikost závisí na impedanci tkáně. Impedance tkáně je dána různými jejími vlastnostmi (druhem, objemem, prokrvením apod.). Bioimpedanční signál nese informaci o těchto vlastnostech [1].

2.2 Elektrody pro měření bioimpedance

Bioimpedance může být měřena tzv. biopotenciálovými elektrodami. Lidské tělo je vodičem druhého druhu, neboť vede proud prostřednictvím volných iontů. V elektrotechnice se však používají vodiče prvního druhu, tedy kovy, které vedou proud volnými elektrony. Snímače tedy musí zajistit spolehlivé vodivé spojení mezi těmito dvěma vodiči.

Biopotenciálové elektrody jsou aktivními snímači, tzn. zdrojem elektrické energie, zdrojem signálu. Tyto elektrody se mohou dělit podle druhu vyšetřované tkáně na povrchové, podpovrchové či mikroelektrody. Nejčastěji používané jsou povrchové elektrody, které jsou určeny pro neinvazivní snímání. Podpovrchové elektrody slouží k invazivnímu snímání nebo trvalé implantaci. Mikroelektrody jsou nejčastěji používány při experimentálních měřeních na izolovaných buňkách či vláknech. Biopotenciálové elektrody lze dále rozdělit podle konstrukčního provedení, jako je použitý elektrodový materiál, mechanické provedení, přizpůsobení místu snímání a druh biosignálu, pro jehož snímání jsou určeny [1].

Při měření bioimpedance se používá obvykle bipolární či tetrapolární zapojení elektrod [2].

3 Elektronická impedanční tomografie


Elektrická impedanční tomografie (EIT) je neinvazivní lékařská metoda, využívající elektrické proudy o frekvencích v určitém rozsahu pro zobrazení elektrických vlastností tkání a vnitřních struktur těla. Na základě různých elektrických vlastností (impedance, konduktivita) jednotlivých tkání existují výrazné rozdíly mezi fyziologickými a patologickými tkáněmi. Toto měření elektrických vlastností přináší nové možnosti v lékařské zobrazovací technice, a to konkrétně v lékařské diagnostice, klinickém vyšetření, screeningu či při kontinuálním monitorování funkcí pacienta u lůžka. Kromě statického zobrazení umožňují některé systémy zaznamenat také dynamické změny nebo vytvořit 3D obraz měřené oblasti [3].

3.1 Princip metody

EIT systém se skládá ze zdroje proudu, dále vysílačích a měřících elektrod, zesilovačů signálů a obvodů pro zpracování signálu. Tato metoda je založená na aplikaci proudu, který prochází přes elektrody umístěné na povrchu těla, které měří výsledné napětí. Z tohoto výsledného naměřeného napětí je možné vytvořit obraz resistivity uvnitř těla v tkáních [3], [4].

Používá se výhradně zdroj střídavého proudu, protože při použití zdroje stejnosměrného proudu by mohlo dojít k vytvoření polarizované vrstvy s nábojem na rozhraní elektroda-povrch těla, což by mělo za následek zkreslení výsledných hodnot. Frekvence zdroje střídavého proudu musí být asi 10 kHz–1 MHz, jinak by nedošlo k propuštění proudu přes membránu buněk. Pro přesnost vyslání proudů do objektu musí mít proudové zdroje ideálně nekonečnou výstupní impedanci. Velikost proudů musí dodržovat určité limity, aby se nepoškodila tkáň a nestimulovala buňky. Toto rozhraní obvykle bývá mezi 0,1 mA–1 mA. Vysílací elektrody vyšlou do objektu střídavé proudy, které uvnitř objektu vyvolají rozložení potenciálu, který je ovlivněn elektrickými vlastnostmi vnitřních struktur objektu. Hladiny se stejným potenciálem (tzv. izopotenciální hladiny) jsou vždy kolmé na směr šíření proudů. Tyto proudy procházejí objektem v uzavřených smyčkách, tudíž splňují Kirchhoffovy zákony. Rozložení izopotenciálních hladin vytváří na povrchu objektu tzv. napěťové profily, které jsou detekovány měřícími elektrodami.

Například při použití 16 elektrod, které jsou umístěny po celém obvodu kruhového média, se k vysílání proudu obvykle používá jedna dvojice elektrod a napětí se potom snímá mezi velkým počtem dvojic elektrod. V tomto případě se získá $16 \times 13 = 208$ měření napětí. Polovina hodnot (tj. 104) je nezávislá, druhá polovina odpovídá převráceným hodnotám [3].



Obr.3.1: Ukázka 16-ti elektrodového systému EIT, kdy se měří napětí V_1 mezi elektrodami až potom, kdy proud I projde přes jádro Ω [4].

3.2 Dopředné řešení a inverzní úloha

Hlavním cílem EIT je vytvořit obraz vnitřního rozložení impedance určitého objektu, k tomuto se využívá dopředného řešení a inverzní úlohy.

Dopředné řešení úlohy je postup v EIT, kdy k nalezení jednoznačného výsledku dojde použitím známého fyzikálního modelu. Úlohy tohoto typu mají obvykle jednoznačné řešení, které není citlivé k malým změnám ve vstupních datech. Tímto se získají pro známou hodnotu konduktivity a zadaný proud hodnoty napětí na povrchu elektrod [5]. V EIT se pro vyřešení dopředné úlohy nejčastěji používá metoda konečných prvků (FEM, Finite Element Method), kdy je měřená oblast rozdělena na několik jednotlivých elementů s různou konduktivitou. Dopředná úloha je potom řešena pro každý element zvlášť [9].

Opakem je inverzní úloha, která lze chápat jako hledání příčiny daného efektu. Tyto inverzní úlohy nemají vždy jednoznačné a stabilní řešení a malé změny ve vstupních datech mohou způsobit velké změny ve výsledku. Touto úlohou lze naopak získat neznámé rozložení konduktivity k zadanému proudu a naměřeným hodnotám napětí [5].

4 Rekonstrukce obrazu

Rekonstrukce obrazu v lékařství se dá realizovat různými způsoby, mezi ty nejznámější patří: Fourierova rekonstrukce, Projekce a Radonova transformace, Prostá zpětná projekce, Filtrovaná zpětná projekce.


U rekonstrukce obrazu v EIT jsou používány různé rekonstrukční metody. Tyto metody se mohou dělit na deterministické, stochastické a rekonstrukce obrazu pomocí neuronových sítí.

Základním problémem pro rekonstrukci obrazu v EIT je nelineární průtok elektrického proudu v nehomogenním prostoru vodiče. Proud se šíří ekvipotenciálními liniemi přes měřený objekt [13].

4.1 Projekce a Radonova transformace

Projekcí daného úhlu $p(x', \phi)$ zobrazovaného objektu $o(x, y)$ se rozumí soubor paprskových integrálů opatřených z jednoho směru snímání. Paprskový integrál představuje celkové zeslabení toku fotonů rtg záření měřený ve sloupci tkáně y' v daných pozicích osy x' (obr.4.1).

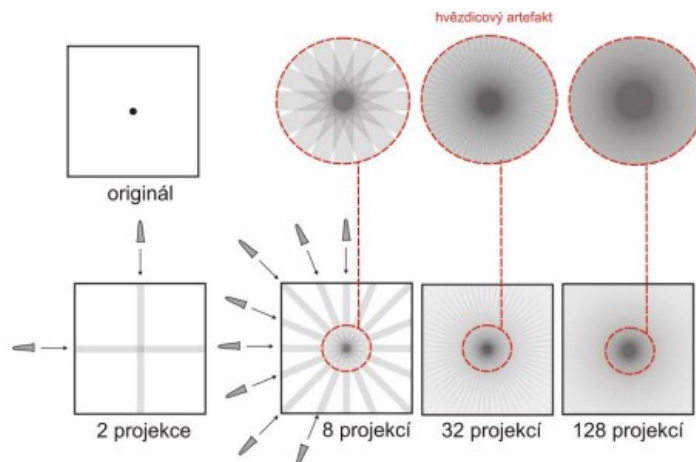
Jednotlivé projekce jsou ukládány do vytyčené oblasti nazývané Radonův prostor. Radonovou transformací se rozumí postupné naplnění Radonova prostoru souborem projekcí snímaných pod měnicími se úhly ϕ . Radonův prostor je v podstatě obrazová matice $f(x, y)$, kde osa x reprezentuje jasovou výchylku (velikost hodnoty pixelu) příslušné projekce v místě měření vzdálené od středu osy x' , osa y představuje úhel pořízené projekce –sinogram. Sinogram slouží pro dočasné uložení dat k následné rekonstrukci obrazu [13].



Obr.4. 1: Projekce, paprskový integrál [13].

4.2 Prostá zpětná projekce

Zpětná projekce je matematický proces založen na trigonometrii, který se snaží o získání obrazu v opačném pořadí než Radonova transformace. Jedná se o nejjednodušší metodu rekonstrukce obrazu. Využívá zpětného promítání jednotlivých projekcí z Radonova prostoru do prázdného prostoru (matice) pod úhlem, pod nímž vznikla. Prostým sečtením těchto matic se získá rekonstruovaný obraz. Nevýhodou této metody je značné rozostření (zkreslení) obrazu, které je způsobeno promítáním jednotlivých projekcí přes celou oblast matice v daném směru označované jako hvězdicový artefakt. Hvězdicový artefakt lze minimalizovat vyšším počtem promítaných projekcí, ale nelze ho odstranit dokonale. Tato metoda se nevyužívá v praxi a její význam je pouze teoretický, avšak je základem pro další metodu – filtrovanou zpětnou projekci nazývanou též inverzní Radonova transformace [13].



Obr.4. 2: Prostá zpětná projekce a vliv počtu projekcí na rekonstruovaný obraz [13].

4.3 Filtrovaná zpětná projekce (Inverzní Radonova transformace)

Filtrovaná zpětná projekce umožňuje zvýraznění hran (detailů) objektu v obraze, minimalizovat zkreslení a zvýšit kontrast obrazu vhodným „ostřicím“ filtrem, čímž dokáže dokonale odstranit hvězdicový artefakt. Za „ostřicí“ filtr je zde považován H-filtr. Tento použitý H-filtr se v této metodě nazývá filter ramp. Nevýhodou této metody je zvýšený výskyt šumu [13].

4.4 Fourierova rekonstrukce

Fourierova rekonstrukce je založena na tzv. projekčním řezovém teorému, který říká, že jednorozměrná Fourierova transformace projekce p_ϕ sejmutá pod daným úhlem je rovna řezu dvojrozměrné Fourierovy transformace obrazu pod týmž úhlem, jakým byla pořízena projekce[13].

4.5 Deterministické metody – elektrická impedanční tomografie

Deterministické metody rekonstrukce obrazu jsou založeny na tzv. regularizaci (proces minimalizace musí být modifikován s cílem získat stabilní řešení). Tato modifikace spočívá v zavedení dalšího matematického členu, díky kterému se daný systém stává méně citlivý k malým změnám získaných měření. Řešení tohoto nového problému sice aproximuje hledané řešení původního problému s větší odchylkou, ale stává se stabilnějším. Mezi tyto metody lze zařadit například Tichonovovu regularizaci (Tikhonov Regularization Method, TRM), metodu založenou na regularizaci totální variací (TV) nebo metodu nastavení úrovně (Level Set Method, LSM) [5].

4.5.1 Metoda Tichonovovy regularizace

Princip TRM regularizace spočívá v doplnění účelové funkce o regularizační člen. Výhodou TR je poměrně rychlá konvergence, prakticky po deseti iteračních krocích je dosaženo ustálených

hodnot. Nevýhodou TR je, že stabilita a přesnost řešení je velmi citlivá na výběr parametru regularizace α a na počáteční hodnotu hledaného vektoru σ , díky skokové změně vektoru σ vznikají ve výsledcích oscilace. Z tohoto důvodu byly vytvořeny další techniky např. metoda totální variace s algoritmem PD-IPM, která se snaží tento nedostatek odstranit [5].

4.5.2 Metoda totální variace

Metoda totální variace (TV) odstraňuje nevýhody TRM. Výhodou je, že umí efektivně potlačit šum a zachytit ostré obrysy objektů bez oscilací. Nevýhodou je, že pro řešení se používá Eulerova rovnice, která je nelineární s rychle se měnícími koeficienty. K rekonstrukci hledaného rozložení minimalizujeme účelovou funkci [5].

4.5.3 Metoda nastavení úrovně

Výhodou této metody je, že společně s použitím regularizační metody např. TRM či metody Totální variace vykazuje výborné výsledky v rekonstrukci obrazu. Nevýhodou této metody je, že samotné její použití vede ke zkresleným výsledkům rekonstrukce obrazu [5].

4.6 Stochastické metody-elektrická impedanční tomografie

Stochastické metody jsou na rozdíl od deterministických metod založeny na využití teorie pravděpodobnosti, heuristických metodách (metody pokus-omyl) nebo genetických algoritmech. Tyto metody zpracovávají hledané parametry jako náhodné veličiny. Mezi stochastické metody patří např. metoda diferenciální evoluce [5].

4.6.1 Metoda diferenciální evoluce

Cílem je nalézt v krocích zvaných „generace“ extrém (globální) účelové funkce. Tato metoda zpracovává hledané parametry jako náhodné veličiny. Výhodou je, že tato metoda není založena na výpočtu prvních a druhých derivací jako např. TRM, proto může opustit lokální extrém, popřípadě se do něj nemusí ani dostat, další výhodou této metody je, že umožňuje bez dalších modifikací pracovat s funkcemi, které nelze analyticky popsat, lze pouze vyhodnotit funkční hodnotu v libovolném bodě, také je snadno implementována, vhodná pro paralelní zpracování a poskytne řešení i pro úlohy jinými metodami neřešitelnými. Nevýhodou této metody je, že zde není žádná záruka optimálního výsledku, může být velmi pomalá, vyžaduje vhodné nastavení většího množství parametrů algoritmu a také výkonově náročnější počítačové zpracování [5].


4.7 Rekonstrukce obrazu pomocí neuronových sítí – elektrická impedanční tomografie

Neuronová síť je v podstatě výpočtový model, kde jednotlivé jednotky-neurony jsou vzájemně propojeny a schopny vypočítat výstup ze vstupních hodnot. Neuronové sítě mají širokou škálu využití, mimo jiné se dají použít pro rekonstrukci obrazu v EIT.

Neuronová síť se musí nejprve natrénovat na tzv. trénovací sadě modelů, která zahrnuje měření napětí a rozložení vodivosti, k tomuto se nejčastěji používá metoda konečných prvků (FEM). Na rozdíl od jiných rekonstrukčních metod v EIT tato metoda nevyžaduje žádné zjednodušené hypotézy o daném problému (jakákoliv inverzní matice vyžaduje regularizaci, množství a formu, která musí být stanovena z matematické formulace a experimentální situace). Metoda neuronových sítí má tu výhodu, že její jednoduchá matematická formulace neklade nároky na žádné tyto předpoklady, tzn. je schopna provést inverzi přímo z FEM a určit daný signál bez jakýchkoliv dalších předpokladů a analýz [10].

5 Neuronové sítě

Neuronové sítě se inspirovaly poznatky o neuronech a nervových sítích živých organismů. Mají schopnost extrahovat a reprezentovat závislosti v datech, které nejsou zřejmé, řešit silně nelineární úlohy, učit se a zobecňovat. Využívají se především ke klasifikaci, regresi a predikci časových řad [7]. Šíření vzruchu probíhá nejčastěji u nervové tkáně na buněčné úrovni u jednotlivých neuronů [1].



Obr.5. 1: Schéma neuron [8].


5.1 Elektrické vlastnosti neuronu

Neurony jsou nervové buňky, v jejichž těle (soma) jsou rozloženy různé orgány, tj. různá vlákna, zrníčka a jádro. Z tohoto buněčného těla vybíhají různými směry výběžky různé délky - nervová vlákna. Nejdelší a nejsilnější výběžek-neurit (axon) odvádí signály z neuronu, naopak kratší a bohatě větvené výběžky-dendrity přivádějí signály k tělu neuronu. Prostřednictvím nervových vláken dochází v živých organismech k přenosu informací mezi receptory, centrální nervovou soustavou a jednotlivými výkonnými orgány. Neurony se mezi sebou spojují tak, že neurity se napojují na dendrity nebo přímo na tělo následujícího neuronu a vznikají tak nervové dráhy. Místo, kde se dva neurony spojí, se nazývá synapse.

Některé neurity, vývojově mladší a zajišťující vyšší nervovou činnost, jsou obklopeny dřevnou pochvou tzv. myelinovou pochvou, která je pokryta jemnou blanou Schwannovou pochvou. Myelinová pochva je po určité vzdálenosti pravidelně přerušována tzv. Ranvierovými zářezy, kde v místech těchto zářezů naléhá Schwannova pochva přímo na axon [1].

5.2 Umělá neuronová síť

Neuronová síť je systém, který se skládá z výpočetních jednotek-neuronů, které jsou mezi sebou propojeny váhami. Tyto váhy mají schopnost učit se na základě trénovacích vzorů, díky kterým umožňují realizovat kvalitativně novou funkci implicitně obsaženou v trénovacích datech. Další důležitou schopností neuronových sítí je schopnost zevšeobecnování (generalizace) získaných poznatků, tzn. schopnost reagovat i na neznámé vstupy, na které nebyla neuronová síť naučena [7].



Obr.5.2: Formální model neuronu, kde x_1, \dots, x_n jsou vstupy, w_1, \dots, w_n jsou váhy spojů, $x_0 = 1$ je formální vstup, θ je práh, $w_0 = -\theta$, ξ je vnitřní potenciál a $y = f(\xi)$ je výstup neuron získaný aplikací aktivační funkce na potenciál [7].

5.3 Typy neuronových sítí

Existuje celá řada typu neuronových sítí, avšak každý druh se hodí na jiný typ úlohy. Mezi základní typy úloh patří klasifikace a regrese (aproximace). Typy neuronových sítí se dále dělí podle přítomnosti „učitele“ na sítě s učitelem a bez učitele.

Mezi nejznámější typy neuronových sítí patří:

- Vícevrstvá perceptronová síť (MLP)
- Hopfieldova síť
- Kohonenovy samoorganizující se mapy
- RBF síť [7].

5.3.1 Vícevrstvá perceptronová síť (Multilayer Perceptron Neural Network – MLP)

Vícevrstvá perceptronová síť je nejrozšířenější a nejpoužívanější neuronová síť. Jejím základním prvkem je neuron, zvaný perceptron. Tento druh sítě patří mezi sítě s učitelem, tzn. trénovací vzory musí kromě vstupních hodnot obsahovat i hodnoty výstupů.

Z hlediska struktury obsahuje tato síť neurony-perceptrony, které jsou uspořádány do vrstev. Perceptron je zvláštním druhem formálního neuronu, který je zároveň obecný výpočetní prvek všech neuronových sítí, jehož vnitřní potenciál je počítán jako vážený součet vstupů


$$\xi = \sum_{i=1}^n w_i x_i - \theta = \sum_{i=0}^n w_i x_i \quad (5.1)$$

a aktivační funkcí je sigmoida

$$f(\xi) = \frac{1}{1+e^{-\lambda \xi}}, \quad (5.2)$$

kde λ je parametr strmosti.


Tento typ sítě se skládá z několika vrstev perceptronů. Sousední vrstvy perceptronů jsou mezi sebou propojeny tak, že tvoří tzv. bipartitní graf, tzn. výstup jednoho neuronu vrstvy je distribuován do vstupů všech perceptronů následující vrstvy. Poslední vrstvě perceptronů se říká výstupní vrstva, ostatní vrstvy neuronu jsou skryté vrstvy. Podle daného typu úloh se volí počet perceptronů i vrstev [7].



Obr.5. 3: Příklad uspořádání vícevrstvé perceptronové sítě [7].

5.3.2 Hopfieldova síť

Hopfieldova síť může být použita například jako autoasociativní paměť a k řešení optimalizačních problémů. Obsahuje přesně tolik neuron, kolik je vstupů resp. výstupů, protože každý neuron je zároveň vstupní i výstupní. Každý výstup neuronu je veden přes váhy w_{ij} , $i = 1, 2, \dots, n$, $j = 1, 2, \dots, n$ na vstup ostatních neuronů, a tak se vytváří uzavřená smyčka. Díky tomuto uspořádání vzniká symetrická cyklická síť a tím i diagonálně symetrická matice vah. Tato síť pracuje s bipolárními (binárními) hodnotami vstupů či výstupů.



Obr.5.4: Struktura Hopfieldovy sítě [7].

Každý neuron počítá svůj vlastní potenciál ξ a aktivuje svůj výstup pomocí aktivační funkce f ve tvaru:


$$f(\xi) = +1, \text{ pokud } \xi \geq 0 \quad (5.3)$$

$$f(\xi) = -1, \text{ pokud } \xi \leq 0 \quad (5.4)$$


[7].

5.3.3 Kohonenova síť

Kohonenovy síť patří mezi síť bez učitele, provádí se zde jen analýza vstupních dat. Síť obsahuje jedinou vrstvu radiálních neuronů v tzv. Kohonenově (kompetiční) vrstvě. Neurony v této vrstvě mají navíc mezi sebou ještě postranní vazby, které jsou uspořádány nejčastěji do zvolené čtvercové topologické mřížky. Všechny vstupy síť jsou plně propojeny s neurony, tzn., že každý neuron má informaci od všech vstupů. Váhy představují souřadnice, které udávají umístění neuronů v prostoru. Počet neuronů je parametrem sítě a je volitelný, v praxi se nejčastěji používá řádově desítek až stovek neuronů. Neurony v této síti vycházejí z formálních neuronů, které nemají práh a mají nejčastěji dvouhodnotový výstup, kdy jen jeden z nich je aktivní [7].



Obr.5.5: Struktura Kohonenovy sítě [7].



Obr.5.6: Příklad uspořádání Kohonenovy sítě se dvěma vstupy a čtvercovou topologickou mřížkou [7].

5.3.4 RBF síť (Radial Basis Functions)


RBF síť představují vícevrstvou neuronovou síť založenou na radiální bazické funkci. Radiální funkce je založena na funkci určitého středu (bodu), která pro argumenty se stejnou vzdáleností od tohoto středu dává stejné funkční hodnoty. RBF síť je tvořena třemi vrstvami neuronových sítí. První (vstupní) neuronová síť slouží pouze k přenosu vstupních hodnot. Druhá (skrytá) vrstva se skládá z tzv. RBF jednotek, které realizují jednotlivé radiální funkce. Třetí (výstupní) vrstva je lineární. Strukturu RBF sítě lze vidět na Obr. 5. 7. , kde $I = (I_1, I_2, \dots, I_M)^T$ jsou vstupy, $O = (O_1, O_2, \dots, O_q)^T$ jsou výstupy sítě, $H = (H_1, H_2, \dots, H_N)^T$ jsou výstupy skryté vrstvy neuron, $C_j = (c_{j1}, c_{j2}, \dots, c_{jM})^T$ je centrum j-tého RBF neuron ve skryté vrstvě. W_{kj} je váha, spojující skrytý neuron j a výstupní neuron k [12]. RBF jednotka může dále obsahovat parametr šířky b . Přechodová funkce se však od perceptronů liší, vnitřní potenciál ξ se nepočítá jako skalární součin

$w \cdot x$, kde x je u ostatních typů neuronových sítí považován za vstup sítě, ale jako vzdálenost vstupního vektoru I od středu c , případně ještě dělená šířkou b

$$\xi = \frac{\|I-c\|}{b} [9]. \quad (5.5)$$

Nejčastěji používanou aktivační funkcí je Gaussova funkce:

$$f(t) = e^{(-t)^2} [7]. \quad (5.6)$$



Obr.5.7: Struktura RBF sítě [12].

6 Návrh řešení

Po prostudování a seznámení se s prostředím a funkcemi softwaru EIDORS [14] budou vygenerovány impedanční modely v prostředí MATLAB k následnému natrénování a otestování neuronových sítí. Software EIDORS poskytuje mimo jiné i algoritmy pro řešení a modelování problémů v elektrické impedanční tomografii. Tyto modely budou vytvořeny metodou konečných prvků (FEM) a následně doplněny o dopředné řešení. Pro vytvoření těchto modelů o 16 elektrodách budou zvoleny různé hodnoty elementů. Jelikož se jedná o 2D modely, tedy o kružnice, polohy daných impedančních skvrn se změní se změnou parametrů ve vzorci pro kružnici (obr.6.1)


$$r^2 = (x - x_0)^2 + (y - y_0)^2, \quad (6.1)$$

kde r je poloměr kružnice,

x, y jsou osy v kartézském souřadném systému,

x_0, y_0 jsou souřadnice výskytu impedanční skvrny.

Různé typy impedančních modelů s rozdílnou polohou impedančních skvrn lze vidět na obr. 6.1.



Obr.6.1: Příklad vygenerovaných impedančních modelů v Matlabu

K rekonstrukci obrazu v EIT pomocí neuronových sítí (vícevrstvá perceptronová síť, Hopfieldova síť, Kohonenova síť a RBF síť) se na těchto modelech budou trénovat neuronové sítě. Neuronové sítě budou vybrány na základě svých parametrů a vhodnosti použití pro rekonstrukci obrazu. V případě rekonstrukce obrazu v elektrické impedanční tomografii byly po zvážení parametrů vybrány pouze dvě neuronové sítě a to RBF síť a vícevrstvá perceptronová síť.

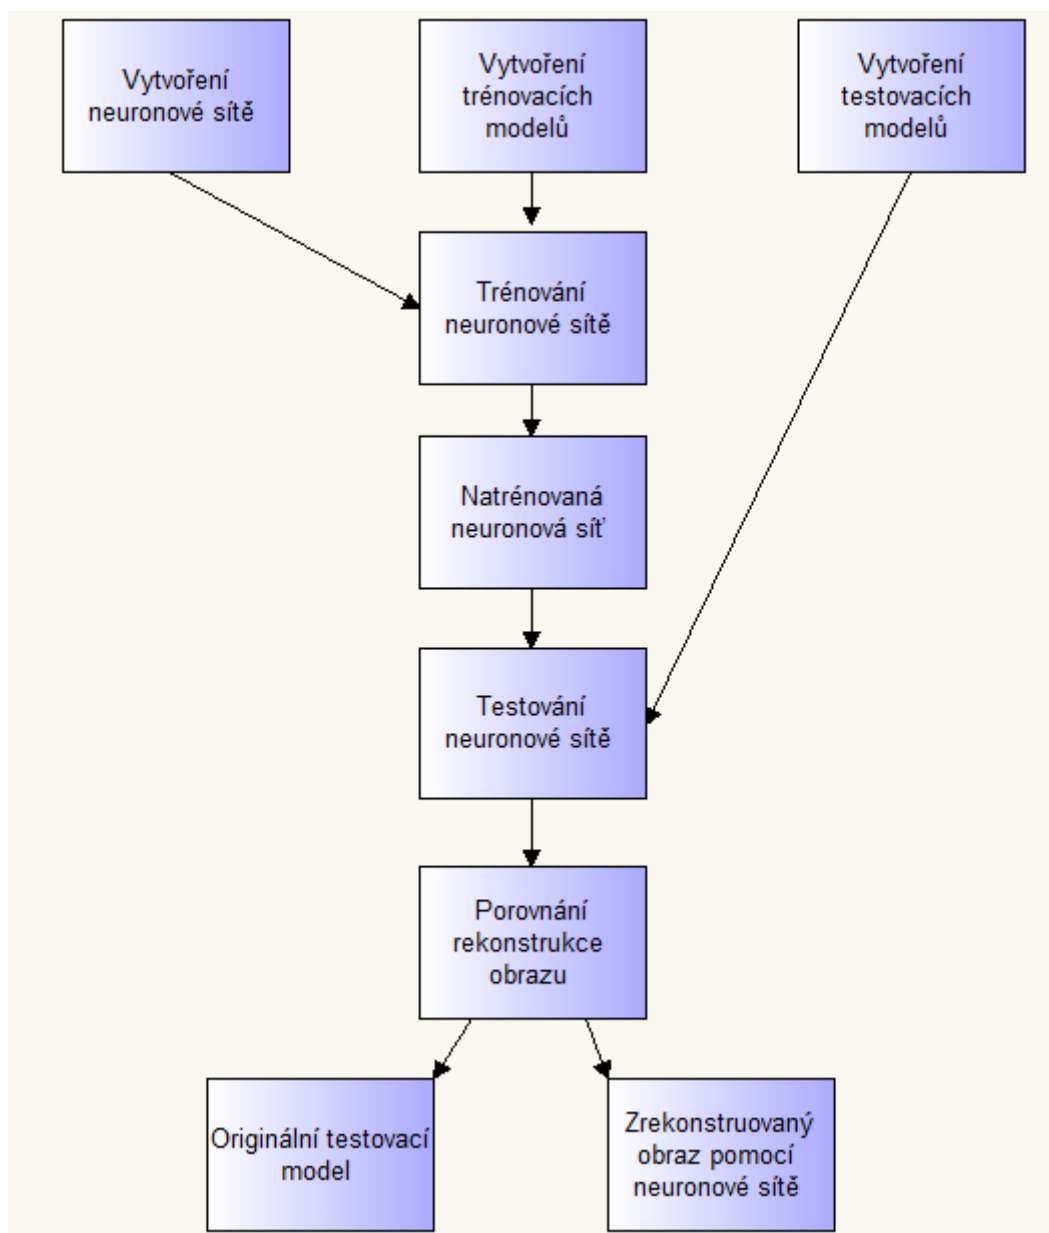
Testování neuronových sítí bude probíhat na testovacích modelech. Tyto modely budou opět vygenerovány v EIDORS. Testovací modely budou odlišné od trénovacích modelů a to jak počtem, tak polohou impedančních skvrn.

Po ukončení trénování neuronových sítí bude každý zrekonstruovaný obraz porovnán s odpovídajícím testovacím modelem.

Pro lepší komunikaci s programem bude navrženo uživatelské rozhraní, kdy si sám uživatel vybere, jakou sadu modelů chce pro natrénování určité neuronové sítě. Dále si zvolí testovací model z konkrétní testovací sady modelů pro rekonstrukci obrazu. Uživatelem vybraný testovací

model se zobrazí na obrazovce společně se zrekonstruovaným obrazem. Pro lepší pochopení a ovládání programu je v tomto rozhraní zahrnuta i nápověda. Nápověda obsahuje informace o funkcích všech tlačítek.

Celkový návrh řešení problému je pro přehlednost znázorněn blokovým schématem na obr. 6. 2.



Obr.6. 2: Blokové schéma návrhu řešení bakalářské práce

7 Realizace

Pro realizaci rekonstrukce obrazu pomocí neuronových sítí bylo třeba vytvořit trénovací sady modelů a následně na ně natrénovat dané neuronové sítě. Dále byly vytvořeny testovací sady modelů, na kterých se neuronové sítě otestovaly a porovnaly s originálním testovacím modelem. Pro lepší přehlednost a usnadnění práce s programem bylo vytvořeno uživatelské rozhraní.

7.1 Generování trénovacích modelů

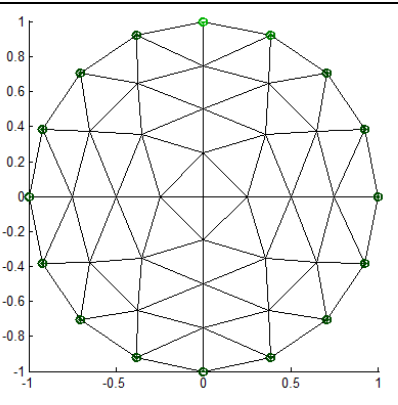
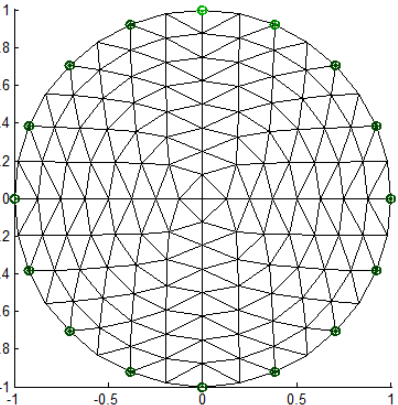
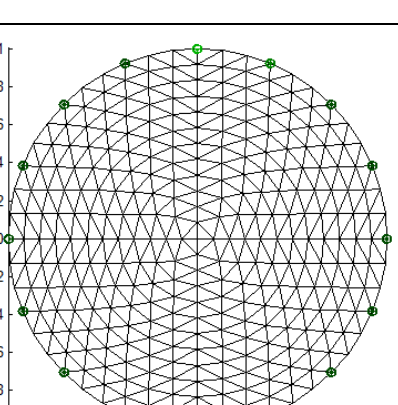
Trénovací modely byly vytvořeny v softwaru EIDORS za účelem následného tréninku neuronových sítí celkem v několika sadách. Pro neuronovou síť typu RBF bylo vytvořeno celkem 5 modelových sad, kdy pro každou tréninkovou modelovou sadu bylo vytvořeno 301 modelů, konkrétně 2D FEM modelů. Pro vícevrstvou perceptronovou síť (MLP) byly vytvořeny jen 2 tréninkové modelové sady a to jen po 41 modelech z důvodu zahlcení neuronové sítě velkým počtem elementů. Jak už bylo řečeno v kapitole 6, na každou trénovací sadu byl použit jiný počet trojúhelníkových elementů. Jiný počet elementů u jednotlivých modelových sad byl použit hlavně z důvodu samotného vyhodnocení rekonstrukce obrazu a následného rozhodnutí, jaký počet elementů pro modelovou sadu je nejvhodnější použít při rekonstrukci v EIT. Jelikož každá modelová trénovací sada obsahovala jiný počet elementů tzn. jiný počet výstupů pro neuronovou síť, musela se neuronová síť vytvořit a natrénovat pro každou modelovou sadu zvlášť. Toto lze provést pomocí modifikace základního funkčního řetězce modelu. Funkční řetězec může vypadat například takto: c2d0c [14]. Parametry tohoto řetězce jsou popsány níže v tab. 7. 1.

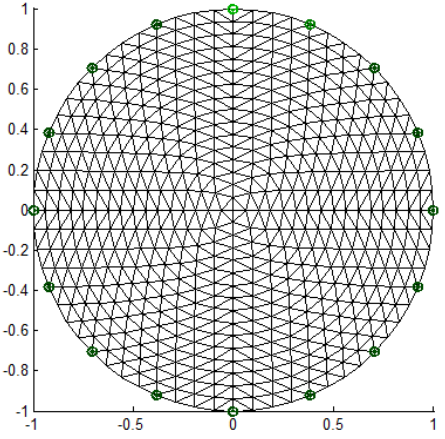
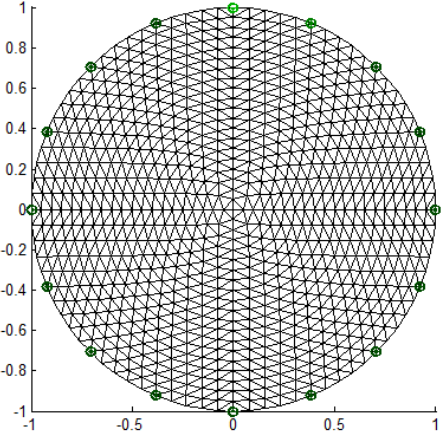
c	hustota sítě modelu (a = nízká hustota, j = vysoká hustota)
2	dvourozměrný model
d	použitý tzv. "distmesh" generátor
0	úroveň upřesnění elektrod je rovna 0 (bez upřesnění)
c	kruhový tvar modelu

Tab.7. 1: Popis parametrů funkčního řetězce [14].

Distmesh generátor se nejčastěji využívá pro trojúhelníkovou či tetraedrickou síť. Umožňuje vytvořit nepravidelnost modelu sítě [17]. Pro tuto práci byly použity modely bez použití distmesh generátoru. Použitím tohoto generátoru by vytvoření jak trénovacích, tak testovacích modelů trvalo mnohonásobně delší dobu.

Každá trénovací sada obsahuje dva vektory, vektor vstupů a vektor požadovaných výstupů. První vektor vyjadřuje 208 vypočtených hodnot v EIDORS, které odpovídají napětí, které by bylo změřeno na takovýchto impedančních modelech, a druhý vektor počtu elementů. Vektor vstupů je tedy 208 vypočtených hodnot napětí společně s modelem, na kterém bylo toto napětí změřeno, a počet elementů je pak vektor požadovaných výstupů. Použité modely jsou zobrazeny v tab. 7. 2.

		Použité FEM modely
Název funkčního řetězce	Počet elementů	Prázdný model
a2c0	64	
b2c0	256	
c2c0	576	

d2c0	1024	
e2c0	1600	

Tab.7. 2: Použité modely pro trénovací a testovací sady

7.2 Trénování neuronové sítě typu RBF

Pro trénink neuronové sítě v této práci byly vybrány pouze neuronové sítě typu RBF a vícevrstvá neuronová síť. Zbylé dvě sítě tj. Hopfieldova a Kohonenova síť jsou pro řešení problému rekonstrukce obrazu v elektrické impedanční tomografii nepřijatelné, jelikož výstupní hodnoty nejsou v průběhu učení sítě porovnávány s požadovanými hodnotami [15]. Vybrané neuronové sítě byly vytvořeny v MATLABU pomocí přesných funkcí.

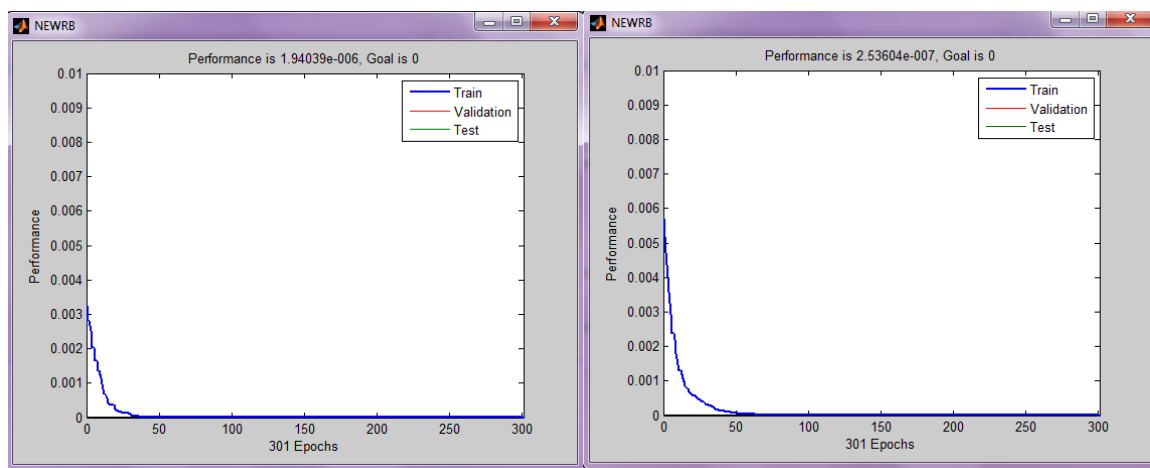
Pro trénink neuronové sítě typu RBF je to funkce newrb, do níž byly zadány tyto parametry:

- P = vstupní vektor
- T = výstupní požadovaný vektor
- goal = cílová chyba (standartní hodnota 0)
- spread = šíření radiálních bazických funkcí (standartní hodnota 1)


Vstupní vektor P je definován jako první řádek trénovacích modelových sad. Výstupní požadovaný vektor T potom vyjadřuje druhý řádek trénovacích modelových sad. Goal je defaultně nastaven na 0 a spread faktor je roven 0, 3.

Čím větší je spread factor, tím hladší je aproximace funkce. Příliš velký spread factor může zavinit numerické problémy.


Na následujících obrázcích jsou vidět průběhy trénování neuronové sítě na jednotlivé sady modelů. U této neuronové sítě je pevně nastaven počet epoch, tzn. že až trénink neuronové sítě dosáhne daného počtu epoch trénování, tak se ukončí.



Obr.7. 1: Natrénovaná neuronová síť typu RBF pro modely funkčního řetězce typu a2c0 (vlevo) a b2c0 (vpravo)



Obr.7. 2: Natrénovaná neuronová síť typu RBF pro modely funkčního řetězce typu c2c0 (vlevo) a d2c0 (vpravo)



Obr.7. 3: Natrénovaná neuronová síť typu RBF pro modely funkčního řetězce typu e2c0

Rychlosti natrénování tohoto typu neuronové sítě na dané trénovací modelové sady jsou vypsány v tabulce níže (viz. tab.7. 3).

Modelová sada	Čas natrénování neuronové sítě
a2c0	190,77 s
b2c0	206,30 s
c2c0	231,85 s
d2c0	277,34 s
e2c0	313,30 s

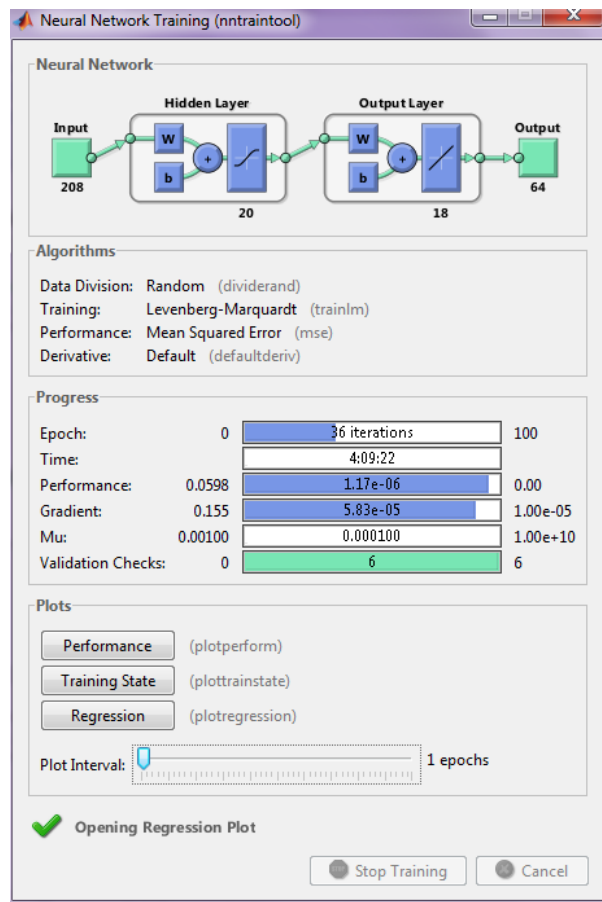
Tab.7. 3: Rychlosti natrénování neuronové sítě typu RBF na dané modelové sady

Rychlost natrénování neuronové sítě typu RBF závisí na počtu elementů modelu. Čím vyšší počet elementů, tím delší doba tréninku neuronové sítě.

7.3 Trénování vícevrstvé perceptronové sítě


Trénink vícevrstvé perceptronové sítě byl realizován pomocí toolboxu nntraintool. Ukázka dialogového okna pro trénování této neuronové sítě lze vidět na obr. 7. 4. Pro trénink vícevrstvé perceptronové sítě funkcí newff byly zadány tyto parametry:

- P = vstupní vektor
- T = výstupní požadovaný vektor
- net1.trainparam.epochs = nastavení počtu epoch [16]



Obr. 7. 4: Ukázka dialogového okna pro trénink vícevrstvé perceptronové sítě pomocí funkce *nntraintool* pro modely funkčního řetězce typu *a2c0*

V grafu trénování vícevrstvé perceptronové sítě lze vidět mimo modré trénovací křivky ještě zelenou a červenou křivku. Zelená validační křivka monitoruje trénink neuronové sítě a červená je křivka testovací. Trénink této sítě se zastaví sám, jakmile dosáhne požadované epochy. Epocha je doba potřebná pro přivedení množiny trénovacích vektorů do neuronové sítě, pro výpočet vah, prahů a chyby učení a pro změnu hodnot vah a prahů [15].



Obr. 7. 5: Natrénovaná vícevrstvá perceptronová síť pro modely funkčního řetězce typu a2c0 (vlevo) a b2c0 (vpravo)

Rychlosti natrénování tohoto typu neuronové sítě na dané trénovací modelové sady jsou vypsány v tabulce níže.

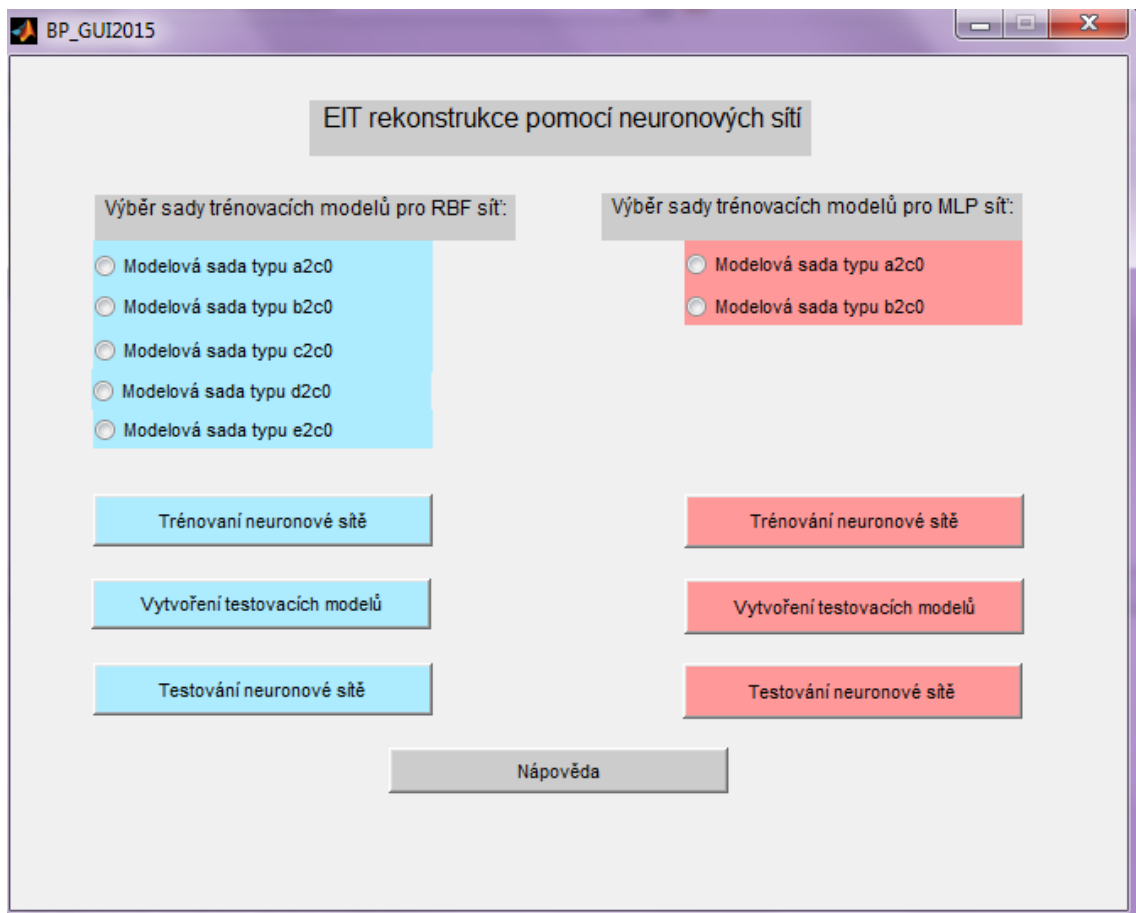
Modelová sada	Čas natrénování neuronové sítě
a2c0	7826 s
b2c0	3261 s

Tab. 7. 4: Rychlosti natrénování vícevrstvé perceptronové sítě na dané modelové sady

Rychlosti natrénování MLP neuronové sítě nezávisí na počtu elementů modelu. Lze konstatovat, že čas pro natrénování tohoto typu neuronové sítě je asi 20–40krát vyšší než u trénování neuronové sítě typu RBF.

7.4 Tvorba uživatelského rozhraní

Uživatelské rozhraní bylo vytvořeno v programovém prostředí MATLAB, pomocí grafického uživatelského rozhraní (GUI). V případě této bakalářské práce bylo využito tlačítek, přepínačů a statických textů. Konkrétně se jedná o tlačítka: Trénování neuronové sítě, Vytvoření testovacích modelů, Testování neuronové sítě a Návoděda. Přepínače jsou potom: Modelová sada typu a2c0, b2c0, c2c0, d2c0, e2c0. Statický text byl použit jako nadpis tohoto rozhraní: EIT rekonstrukce pomocí neuronových sítí a dále jako nadpis pro přepínače: Výběr sady trénovacích modelů pro RBF síť a Výběr sady trénovacích modelů pro MLP síť. Uživatelské rozhraní je na obr. 7.6.



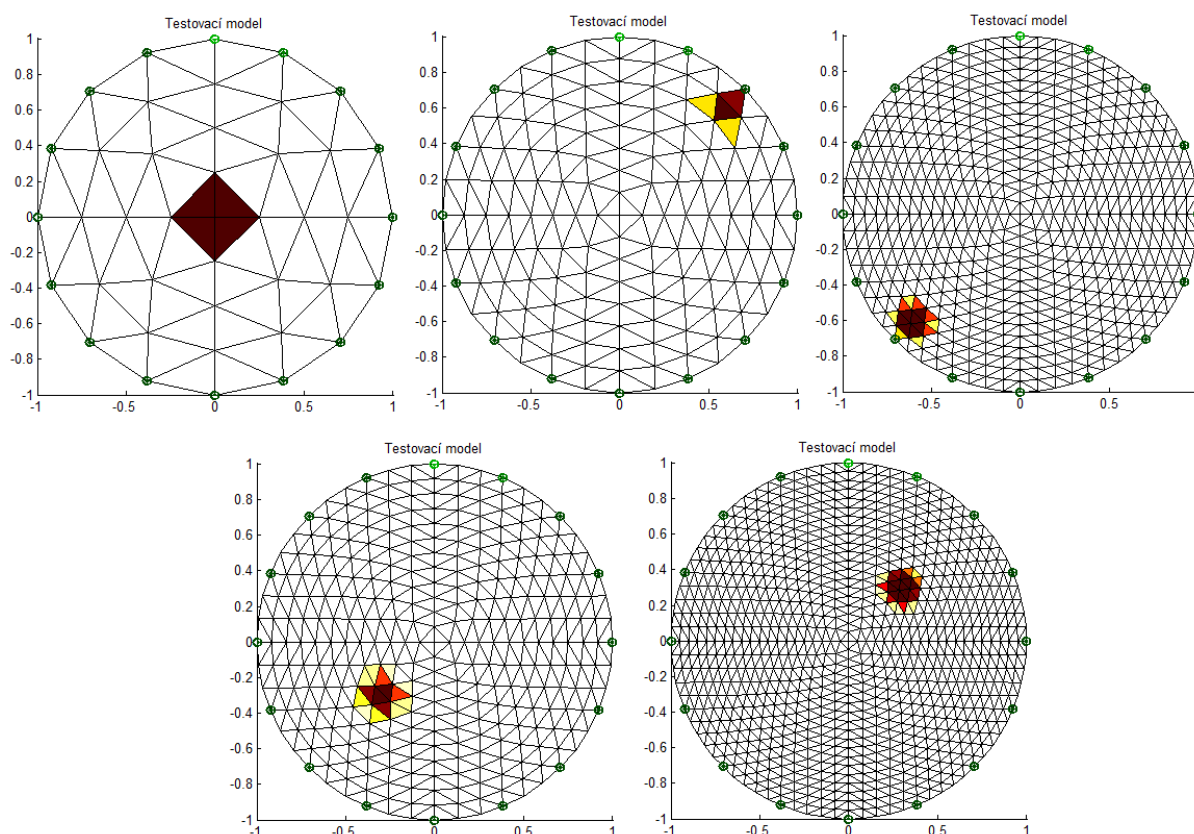
Obr. 7. 6: Uživatelské rozhraní

8 Testování

Pro testování bylo vytvořeno 5 modelových testovacích sad s různým počtem elementů pro každou neuronovou síť. Na testování bylo vygenerováno a použito celkem 547 testovacích modelů. Jako vstupní data do neuronové sítě pro rekonstrukci bylo použito 208 hodnot napětí na elektrodách vypočtených pomocí softwaru EIDORS. Neuronová síť na základě těchto vstupů dá výstupy ve formě impedance jednotlivých elementů. Když tyto výstupní hodnoty byly poskládány zpět do obrazu, byl zrekonstruován výsledný obraz pomocí neuronové sítě.

8.1 Generování testovacích modelů

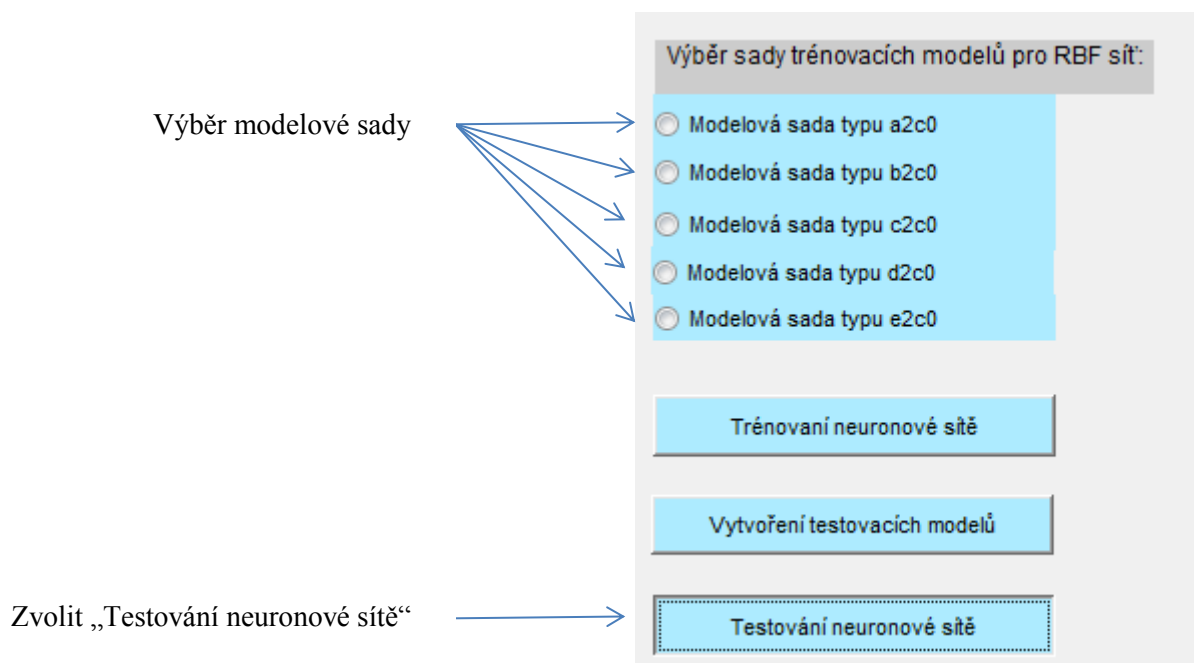
Testovací sady modelů byly rovněž vytvořeny pomocí softwaru EIDORS, avšak tyto modely nejsou zcela totožné s trénovacími modely, jelikož jsou generovány za účelem testování neuronové sítě. Stejně jako u trénovacích modelových sad se pracuje se sadami modelů, jejichž počet pro dané neuronové síť koresponduje s trénovacími sadami. Každá testovací sada je tvořena různým počtem trojúhelníkových elementů, jak lze vidět v tab. 7. 2. Příklady testovacích modelů o různé hodnotě trojúhelníkových elementů jsou zobrazeny na obr. 8. 1.



Obr.8. 1: Příklady vytvořených testovacích modelů

8.2 Testování neuronové sítě typu RBF


Neuronová síť, která je natrénována na daný typ trénovacích modelů, je načtena. Spolu s neuronovou sítí je rovněž načtena příslušná sada testovacích modelů. Pro uživatele to tedy znamená výběr dané modelové sady a kliknutí na tlačítko „Vytvoření testovacích modelů“ v uživatelském rozhraní.




Obr.8. 2: Ukázka testování neuronové sítě v uživatelském rozhraní

V případě neuronové sítě typu RBF byly síť natrénovány a otestovány na 5 sadách modelů. Kdy každá sada obsahuje 101 modelů. Kdyby tato neuronová síť ještě nebyla natrénována, trénovací a testovací modely nebyly vytvořeny, vytvoří a natrénují se znovu.


Uživateli se zobrazí dialogové okno (obr. 8. 2), kde má možnost si vybrat testovací model, který chce pomocí neuronové sítě zrekonstruovat (obr. 8. 3). V případě neuronových sítí typu RBF může zvolit testovací model číslo 1-101. Zrekonstruovaný a testovací model vybraný uživatelem lze vidět na obr.8. 4.



Obr.8. 3: Dialogové okno



Obr.8. 4: Dialogové okno, kdy uživatel zadal testovací model číslo 50




Obr.8. 5: Příklad testovacího modelu b2c0 č.101 (vlevo) a zrekonstruovaného modelu (vpravo)

8.3 Testování vícevrstvé perceptronové sítě

Proces testování vícevrstvé perceptronové sítě probíhá úplně stejně jako u neuronové sítě typu RBF. Rozdíl je opět v počtu modelů v jednotlivých modelových sadách. V každé ze 2 modelových testovacích sad je 21 modelů.

Po výběru dané modelové sady a výběru konkrétního testovacího modelu uživatelem se zobrazí testovací model a zrekonstruovaný model dle vícevrstvé perceptronové sítě, jak lze vidět na obr.8. 5. Pro vícevrstvou perceptronovou síť uživatel zvolí číslo modelu 1-21.



Obr.8. 6: Příklad testovacího modelu b2c0 č.21 (vlevo) a zrekonstruovaného modelu (vpravo)

9 Vyhodnocení rekonstrukce obrazu

Testovací a zrekonstruované modely pomocí daných neuronových sítí byly porovnány a zhodnoceny jak po vizuální stránce, tak i početně.

Byla vypočtena MSE podle vzorce:

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{Y}_i - Y_i)^2, \quad (8.1)$$

kde

\hat{Y}_i = vektor testovacích modelů,


Y_i = vektor zrekonstruovaných modelů danou neuronovou sítí,

N = počet elementů


pro každý zrekonstruovaný obraz vzhledem k originálnímu modelu vygenerovanému pomocí EIDORS.

9.1 Vyhodnocení rekonstrukce obrazu pro neuronovou síť typu RBF


Zrekonstruované obrazy pomocí této neuronové sítě vykazují výborné výsledky rekonstrukce obrazu. Rozdíl mezi zrekonstruovaným obrazem neuronovou sítí a testovacím modelem vygenerovaným v EIDORS dle výpočtu MSE je skoro nulový (viz.tab. 9. 1) Pouhým okem lze vidět mírně světlejší odstíny barev impedanční skvrny u zrekonstruovaného modelu. Testovací a zrekonstruované modely pomocí neuronové sítě typu RBF lze vidět na následujících obrázcích.



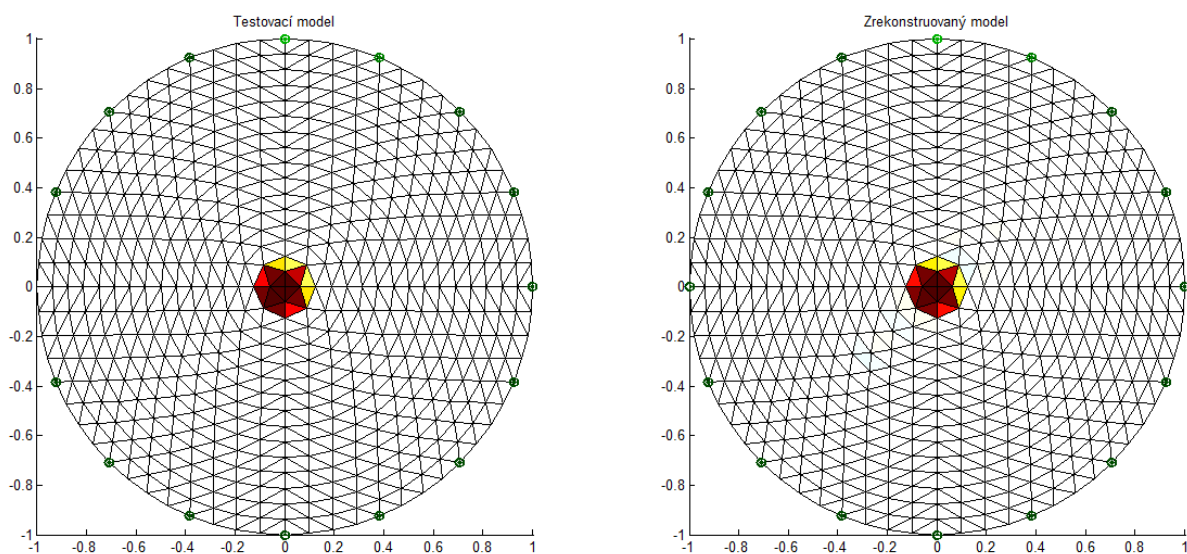
Obr.9. 1: Testovací model č. 20 (vlevo) a zrekonstruovaný obraz (vpravo) neuronovou sítí typu RBF pro 64 elementů




*Obr.9. 2: Testovací model č. 30 (vlevo) a zrekonstruovaný obraz (vpravo)
neuronovou sítí typu RBF pro 256 elementů*



*Obr.9. 3: Testovací model č. 40 (vlevo) a zrekonstruovaný obraz (vpravo)
neuronovou sítí typu RBF pro 576 elementů*



Obr.9. 4: Testovací model č. 50 (vlevo) a zrekonstruovaný obraz (vpravo) neuronovou sítí typu RBF pro 1024 elementů




Obr.9. 5: Testovací model č. 60 (vlevo) a zrekonstruovaný obraz (vpravo) neuronovou sítí typu RBF pro 1600 elementů

Tento nepatrný rozdíl dokazuje i tab. 9. 1 pro všechny testovací modelové sady. Je zde vypočtena MSE a směrodatná odchylka zrekonstruovaných modelů vzhledem k testovacím. MSE je dále znázorněna pomocí krabicového grafu pro všechny modelové sady na obr. 9. 6.

Typ modelu	Počet elementů	Medián	Minimum	Maximum	Směrodatná odchylka
a2c0	64	0,0006	$2,2391 \cdot 10^{-14}$	0,0056	0,0016
b2c0	256	$6,9371 \cdot 10^{-5}$	$1,9399 \cdot 10^{-11}$	0,0069	0,0015
c2c0	576	$6,9833 \cdot 10^{-5}$	$5,4244 \cdot 10^{-10}$	0,0056	0,0013
d2c0	1024	0,0001	$9,1482 \cdot 10^{-10}$	0,0069	0,0017
e2c0	1600	$7,241 \cdot 10^{-5}$	$3,1009 \cdot 10^{-8}$	0,0083	0,0018

Tab.9. 1: Tabulka vypočtených hodnot MSE a směrodatné odchylky pro neuronovou síť typu RBF




Obr.9. 6: Vyjádření hodnot MSE pro všech 5 modelových sad v krabicových grafech pro neuronovou síť typu RBF


Z početních i grafických výstupů lze konstatovat, že nejlepší rekonstrukční vlastnosti vykazuje modelová sada c2c0. Obecně lze říci, že čím větší počet elementů, tím lepší rozlišení obrazu. Avšak s ohledem na dobu trénování neuronové sítě a samotného vygenerování modelů jsou výhodnější modelové sady s menším počtem elementů. Proto pro rekonstrukci obrazu dle nejmenší rekonstrukční chyby, generování modelů a rychlosti natrénování neuronové sítě typu RBF lze vyhodnotit jako nejlepší modelovou sadu b2c0, tedy modely s 256 elementy.

9.2 Vyhodnocení rekonstrukce obrazu pro vícevrstvou perceptronovou síť

Vícevrstvá perceptronová síť zrekonstruovala obrazy testovacích modelů s menší přesností. U této neuronové sítě je viditelný rozdíl mezi testovacím a zrekonstruovaným modelem. Testovací a zrekonstruované modely pomocí vícevrstvé perceptronové sítě lze vidět na následujících obrázcích.



Obr.9. 7: Vybraný testovací model č. 10 (vlevo) a zrekonstruovaný obraz (vpravo) neuronovou sítí typu MLP pro 64 elementů




Obr.9. 8: Vybraný testovací model č. 20 (vlevo) a zrekonstruovaný obraz (vpravo) neuronovou sítí typu MLP pro 256 elementů

Tento viditelný rozdíl v rekonstrukci obrazu u tohoto typu sítě je znatelný i v tab. 9. 2 a na obr. 9. 9. v krabicových grafech pro MSE obou modelových sad.

Typ modelu	Počet elementů	Medián	Minimum	Maximum	Směrodatná odchylka
a2c0	64	0,0001	$9,7291 \cdot 10^{-7}$	0,0006	$1,8829 \cdot 10^{-4}$
b2c0	256	0,0001	$4,1413 \cdot 10^{-6}$	0,0072	0,0016

Tab.9. 2: Tabulka vypočtených hodnot MSE a směrodatné odchylky pro neuronovou síť typu MLP



Obr.9. 9: Vyjádření hodnot MSE pro obě dvě modelové sady v krabicových grafech pro neuronovou síť typu MLP


U tohoto typu neuronové sítě lze konstatovat z grafických a početních výstupů, že lepší rekonstrukční vlastnosti vykazuje modelová sada a2c0. Tento rozdíl od modelové sady b2c0 lze vidět, hlavně v maximu a minimu MSE, kdy je tento rozdíl v řádech tisícín. Doba natrénování této sítě je značná, může trvat až několik hodin. Z tohoto pohledu je výhodnější využít pro rekonstrukci obrazu neuronovou síť, která je natrénovaná na sadu b2c0, tedy 256 elementů. Čas natrénování sítě na tuto sadu je totiž poloviční. Pro rekonstrukci obrazu pomocí neuronové sítě typu MLP je lepší zvolit sadu s vyšším počtem elementů, v našem případě tedy b2c0 pro 256 elementů.

9.3 Porovnání výsledků rekonstrukce obrazu

Porovnání dvou použitých neuronových sítí proběhlo jen u dvou modelových sad. Vzhledem k počtu natrénovaných vícevrstevných perceptronových sítí lze porovnat pouze testování neuronových sítí pro modelové sady typu a2c0 (64 elementů) a b2c0 (256 elementů). Porovnat tyto rekonstrukce

obrazu pomocí neuronových sítí lze vizuálně z přiložených obrázků, početně z tabulek a také graficky z krabicových grafů.

Vždy je porovnána daná rekonstrukce obrazu pomocí neuronové sítě typu RBF a MLP s originálním testovacím modelem. Vizuálně lze říci, že lepší rekonstrukční vlastnosti vykazuje neuronová síť typu RBF. Hodnoty impedance elementů jsou barevně kódovány, takže si lze všimnout lehké změny v sytosti barev elementů ve zrekonstruovaném obrazu. Bez delšího zkoumání lze říci, že zrekonstruovaný obraz touto neuronovou sítí je téměř totožný. Tento fakt však vyvrací početní porovnání rekonstrukce, jak lze vidět v tab. 9. 3.




Obr. 9. 10: Porovnání rekonstrukce obrazu vizuálně pro 64 elementů

Dle výpočtu střední kvadratické chyby a směrodatné odchylky se jeví obě neuronové sítě jako rekonstrukčně stejně kvalitní. Rozdíly hodnot se pohybují v řádech tisícín. Například rozdíl hodnot u mediánu MSE mezi sítěmi se pohybuje okolo 5 tisícín. Toto lze pozorovat také z grafického vyjádření porovnání na obr. 9. 11, kdy median MSE neuronové sítě RBF je vyšší než u MLP sítě. Tato rozdílnost mezi vizuálním porovnáním a početním může být způsobena horšími rekonstrukčními vlastnostmi neuronové sítě typu RBF pro malý počet elementů.


Modelová sada a2c0	Neuronová síť typu RBF	Neuronová síť typu MLP
Medián	0,0006	0,0001
Minimum	$2,2391 \cdot 10^{-14}$	$9,729 \cdot 10^{-7}$
Maximum	0,0056	0,006
Směrodatná odchylka	0,0016	$1,8829 \cdot 10^{-4}$

Tab.9. 3: Porovnání rekonstrukce obrazu pomocí MSE a směrodatné odchylky pro 64 elementů



Obr.9. 11: Porovnání rekonstrukce obrazu graficky pomocí vyjádřených MSE krabicovými grafy pro 64 elementů

U modelové sady b2c0 lze jako lepší neuronovou síť pro rekonstrukci obrazu vizuálně vybrat opět síť typu RBF. Stejně jako u modelové sady a2c0 si lze všimnout lehké odlišnosti v sytosti barev impedance u daných elementů v rekonstruovaném obrazu. Tato skutečnost je vidět na následujícím obrázku viz. obr.9. 12.




Obr.9. 12: Porovnání rekonstrukce obrazu vizuálně pro 256 elementů

Co se týče početního (viz. tab. 9. 4) i grafického porovnání (viz. obr. 9. 13) rekonstrukce obrazu pomocí neuronových sítí, tak vizuální stránka rekonstrukce zde zcela odpovídá. Tedy opět vykazuje lepší výsledky rekonstrukce neuronová síť typu RBF. Lze takto usoudit dle výpočtu mediánu

MSE, kdy vykazuje neuronová síť typu MLP až 10 krát větší chybu. Dále i pro maximum a minimum MSE je neuronová síť typu RBF výhodnější a lepší vzhledem až k 50 krát menší minimální MSE a o pár setin menším maximu MSE. Směrodatná odchylka je také o tisícínu menší u sítě RBF než u sítě MLP.

Modelová sada b2c0	Neuronová síť typu RBF	Neuronová síť typu MLP
Medián	$6,9371 \cdot 10^{-5}$	0,0001
Minimum	$1,9399 \cdot 10^{-11}$	$4,1413 \cdot 10^{-6}$
Maximum	0,0069	0,0072
Směrodatná odchylka	0,0015	0,0016

Tab.9. 4: Porovnání rekonstrukce obrazu pomocí MSE a směrodatné odchylky pro 256 elementů



Obr.9. 13: Porovnání rekonstrukce obrazu graficky pomocí vyjádřených MSE krabicovými grafy pro 256 elementů

10 Závěr

Cílem bakalářské práce bylo provést rekonstrukci obrazu z naměřených dat v elektrické impedanční tomografii, tedy z dat vypočtených pomocí softwaru EIDORS. Rekonstrukce obrazu byla provedena pomocí vybraných neuronových sítí a následně porovnána s vygenerovanými impedančními modely.

Návrh byl proveden tak, že se vygenerovaly sady impedančních modelů o různém počtu trojúhelníkových elementů. Po prostudování problematiky neuronových sítí byly vybrány dvě neuronové sítě, a to neuronová síť typu RBF a vícevrstvá perceptronová síť (MLP), které svými parametry odpovídají rekonstrukci obrazu v EIT. Pro lepší ovladatelnost a přehlednost celého programu bylo vytvořeno uživatelské prostředí.

Natrénování vybraných neuronových sítí se realizovalo po vyřešení dopředné úlohy pro získání hodnot napětí na elektrodách na vygenerovaných trénovacích modelových sadách. Neuronová síť typu RBF byla natrénována na 5 trénovacích sad o 301 modelech a MLP neuronová síť na 2 trénovací sady o 41 modelech. Každý trénink neuronové sítě na danou trénovací modelovou sadu trval jiný časový úsek. Pro neuronovou síť typu RBF se doba natrénování neuronové sítě pohybovala v řádech sekund. Trénink vícevrstvé perceptronové sítě trval podstatně delší dobu, trénink na jedné sadě modelů trval této neuronové síti několik hodin.

Pro otestování jednotlivých neuronových sítí byly vygenerovány testovací modelové sady, ovšem zde pro obě neuronové sítě byly vytvořeny stejné sady o stejném počtu modelů. Tedy bylo vytvořeno 5 testovacích sad po 101 modelech.

Kapitola testování potvrdila, že lepších rekonstrukčních výsledků obrazu v EIT dosáhla neuronová síť typu RBF. Na základě vizuálního porovnání testovacího a zrekonstruovaného modelu nebylo shledáno skoro žádného rozdílu. Nepatrný rozdíl je jen v sytosti barev impedance elementů, kdy se tyto od sebe liší v řádech desetin, tedy jen nepatrně. Tyto malé změny v rekonstrukci obrazu neuronovou sítí typu RBF jsou znázorněny početně pomocí střední kvadratické chyby a směrodatné odchylky zrekonstruovaných modelů k testovacím modelům. Výsledky ukazují téměř nulovou chybu v rekonstrukci obrazu. Konkrétně medián střední kvadratické chyby se pohybuje v řádu 10^{-5} . Z těchto výsledků je dale patrné, že neuronová síť typu RBF disponuje směrodatnou odchylkou řádově kolem 10^{-3} . Při testování vícevrstvé perceptronové sítě lze vidět větší vizuální rozdíly v testovacím a zrekonstruovaném modelu. Toto je také stejně početně prokázáno v tabulkách pro MSE a směrodatnou odchylku. U této sítě se pohybuje medián střední kvadratické chyby v řádu 10^{-4} . Podobnou velikostí jako u neuronové sítě typu RBF disponuje směrodatná odchylka, která u neuronové sítě typu MLP se pohybuje také v řádu 10^{-3} .

Po otestování a porovnání těchto dvou neuronových sítí lze konstatovat, že pro problém rekonstrukce obrazu z naměřených dat v elektrické impedanční tomografii je vhodnější použít neuronovou síť typu RBF. Konkrétně tedy neuronovou sítí, která je natrénována na modelovou sadu b2c0, tedy na 256 modelů. RBF neuronová síť nejenže vykazuje lepší rekonstrukční vlastnosti po vizuální, početní a grafické stránce, ale také disponuje podstatně kratší trénovací dobou neuronové sítě na rozdíl od vícevrstvé perceptronové sítě.

11 Použitá literatura

- [1] PENHAKER, Marek a Martin AUGUSTYNEK. *Zdravotnické elektrické přístroje I*. 1. vyd. Ostrava: Vysoká škola báňská - Technická univerzita Ostrava, 2013, 411 s. ISBN 978-80-248-3107-7.
- [2] GRIMNES, Sverre a Orjan G. MARTINSEN. *Bioelectricity and bioimpedance basics*. 2nd ed. London: Academic, 2008. ISBN 978-012-3740-045.
- [3] *Elektrická impedanční tomografie*. Brno: Biofyzikální ústav LF MU, 2013. Dostupné z: <http://www.med.muni.cz/biofyz/zobrazovacimetody/files/EIT.pdf>
- [4] STACEY, Robert W. *Electrical Impedance Tomography*. Stanford University, 2006. Dostupné z: <https://pangea.stanford.edu/ERE/research/geoth/publications/techreports/SGP-TR-182.pdf>. Akademická práce. Stanford University.
- [5] DĚDKOVÁ, Jarmila. *Metody rekonstrukce obrazu založené na elektrické impedanční tomografii: Image reconstruction methods based on electrical impedance tomography : teze přednášky k profesorskému jmenovacímu řízení v oboru Teoretická elektrotechnika*. Brno: VUTUM, 2007. 20 s. ISBN 978-80-214-3384-7. Teze přednášky k profesorskému jmenovacímu řízení. VUT Brno.
- [6] MALMIVUO, Jaakko a Robert PLONSEY. *Bioelectromagnetism* [online]. Oxford University Press, 1995 [cit. 2014-09-21]. Dostupné z: <http://www.bem.fi/book/>
- [7] MAŘÍK, Vladimír, O ŠTĚPÁNKOVÁ a Jiří LAŽANSKÝ. *Umělá inteligence*. 1. vyd. Praha: Academia, 2003, 475 s. ISBN 80-200-1044-0.
- [8] WILLIAMS, WILKINS. *SmartDraw.com* [online]. [cit. 21.9.2014]. Dostupný na WWW: <http://www.smartdraw.com/examples/view/motor+neuron+of+the+nervous+system/>
- [9] ŠÍMA, J a Roman NERUDA. *Teoretické otázky neuronových sítí*. Praha, 1996, 390 s. ISBN 80-858-6318-9.
- [10] XU, Guizhi, Qing WU, Qingxin YANG, Ying LI a Weili YAN. A reconstruction algorithm based on wavelet network in electrical impedance tomography. *The 26th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. 2004. DOI: 10.1109/iembs.2004.1403444.
- [11] ADLER, A. a R. GUARDO. A neural network image reconstruction technique for electrical impedance tomography. *IEEE Transactions on Medical Imaging*. 1994, vol. 13, issue 4, s. 594-600. DOI: 10.1109/42.363109.
- [12] WANG, Peng, Hong-li LI, Li-li XIE a Yi-cai SUN. The Implementation of FEM and RBF Neural Network in EIT. *2009 Second International Conference on Intelligent Networks and Intelligent Systems*. IEEE, 2009, s. 66-69. DOI: 10.1109/ICINIS.2009.26. Dostupné z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=5365675>
- [13] VALA, Peter. *Měření multifrekvenční elektrické impedanční tomografie*. Ostrava, 2013. Diplomová práce. VŠB-TUO.
- [14] EIDORS: Electrical Impedance Tomography and Diffuse Optical Tomography Reconstruction Software. *EIDORS: Electrical Impedance Tomography and Diffuse Optical*

- Tomography Reconstruction Software* [online]. 2013-08-16 [cit. 2015-01-15]. Dostupné z: <http://eidors3d.sourceforge.net/>
- [15] TUČKOVÁ, Jana. *Vybrané aplikace umělých neuronových sítí při zpracování signálů*. Vyd. 1. Praha: České vysoké učení technické v Praze, 2009, 224 s. ISBN 978-80-01-04229-8.
- [16] *MathWorks - MATLAB and Simulink for Technical Computing* [online]. 1994 [cit. 2015-03-11]. Dostupné z: www.mathworks.com
- [17] PERSSON, Per-Olof. *DistMesh - A Simple Mesh Generator in MATLAB* [online]. Department of Mathematics, UC Berkeley, 2012 [cit. 2015-03-29]. Dostupné z: <http://persson.berkeley.edu/distmesh/>

12 Seznam příloh

Příloha 1 – CD s programem